”,,Echtzeit“ ist ein Buzzword und sagt gerade bei Nichtrealtime-Betriebssystemen garnichts aus. ”
(Thomas Ogrisegg in at.linux)

Linux PREEMPT_RT

Linux Realtime Patchset

Florian Westphal

15. November 2007

1024D/F260502D <fw@strlen.de>
1C81 1AD5 EA8F 3047 7555
E8EE 5E2F DA6C F260 502D

Themenübersicht

- Einführung: Was ist 'Echtzeit'
- Latenz & Reaktionszeit
- Synchronisation/Locking
- Kernel Preemption
- -rt
- Besonderheiten von RT-Anwendungen

Echtzeit

- Echtzeit $\neq$ (besonders) schnell
- Echtzeit-System muss auf Ereignis innerhalb eines vorgegebenen Zeitrahmens reagieren
- garantierte (Reaktions-)Zeiten

$\rightarrow$ Zuverlässigkeit, deterministisches Verhalten

- auch unter ungünstig und/oder unwahrscheinlichen Bedingungen
- Linux ist für "Common Case" optimiert

Linux RT Ansätze

1. Linux Kernel als 'Prozess' unter einem Realtime-Betriebssystem

   $\longrightarrow$ Kernel darf arbeiten, wenn keine RT-kritische Aktion ausgeführt wird
   $\longrightarrow$ RT-kritische SW läuft außerhalb des Linux Kernels

2. Linux parallel zu RTOS auf eigener CPU

3. Linux `-rt` Patches (aka `PREEMPT_RT`)

Latenz und Reaktionszeit

Latenz: Zeitspanne zwischen Stimulus & Reaktion, z.B.

- Interrupt-Latenz: Zeit zwischen auftreten und Verarbeitung eines Interrupts
- Scheduling-Latenz: Zeitspanne zwischen aufwecken d. Prozesses und dem Zeitpunkt an dem der Prozess losläuft

Reaktionszeit wird auch durch

- Dauer von Interrupt-Handlern, Anzahl von Interrupts, etc.
- Zeit die das Scheduling selbst benötigt (Entscheidung, Kontextwechsel, etc.) beeinflusst.

Ausflug: Linux & präemptives Multitasking

- Unix (und Linux) unterstützen Preemptives Multitasking
- . . . aber das bezieht sich 'nur' auf Prozesse, nicht auf Kernel-Code
- Linux 2.4: Nachdem ein Prozess einen Syscall ausführt, ändert sich der laufende Prozess nicht "unerwartet".
  Scheduling kann nur in 3 Fällen stattfinden:
  1. Programm wird im Userspace ausgeführt
  2. Programm wechselt von Kernel-Mode zurück in Userspace
  3. Kernel-Modus führt explizite Anweisung („`schedule()`“) aus (z.B. weil auf Hardware gewartet werden muss)
- Ausnahme: Interrupts unterbrechen laufenden Code

Kerneltask-Synchronisation mit Interrupts

Code der Form "`counter++`" ist nicht $atomar$:

```
movl counter, %eax
incl %eax
movl %eax, counter
```

Beispiel: Senderoutine inkrementiert Sende-Warteschlangenzähler
Interrupt Handler dekrementiert diesen.

Beispiel

1. Senderroutine will inkrementieren: `movl counter, %eax` (läd Wert in Register, z.B. `1`)

2. Interrupt trifft ein, Unterbrechung $\rightarrow$ Wert wird erneut in Register geladen, dekrementiert und gespeichert: jetzt `0`

3. Nach Ende des Interrupt Handlers läuft Senderoutine wieder an – diese Arbeitet mit dem Wert `1`

4. "Wer zuletzt schreibt, schreibt am besten": Zähler steht nun auf 2

(Historische) Lösung: Interrupts blockieren

```
local_irq_disable();
counter++;
local_irq_enable();
```

Bei SMP-Systemen reicht dies nicht aus:

- Der Interrupt-Handler kann von einer anderen CPU bearbeitet werden
- mehrere CPUs könnten die Senderoutine simultan ausführen

Auf SMP Systemen ...

CPU 0	CPU1
`movl counter, %eax`	
	`movl counter, %eax`
`incl %eax`	
	`incl %eax`
`movl %eax, counter`	
	`movl %eax, counter`

→ Eine Addition geht verloren
→ Der Abschnitt darf nur jeweils von einer CPU ausgeführt werden (,,kritischer Abschnitt")

Spinlocks

- Synchronisationsmechanismus: Nur ein Task kann von `spin_lock(&lock)` "gesicherten" Abschnitt ausführen
- nutzt "atomare" CPU-Instruktion (z.B. `xchg`, lock prefix)
- Busy-Wait: Threads warten "aktiv" auf Lock-Freigabe → blockiert CPU
  - spinlocks nur für kurze Abschnitte verwenden
  - Thread, der spinlock hält, darf nicht "schlafen", also insb. keine Scheduler-Aufrufe
- Falls Synchronisation auch mit Interrupt-Kontext erforderlich: `spin_lock_irqsave()`
- Einprozessor-System: kein Spinlock notwendig

Mutexe: Wenns mal länger dauert..

Mutexe sind spinlocks ähnlich. Wichtigste Unterschiede:

- Task darf (während Mutex gehalten wird) blockieren
- jeder Mutex verfügt über Warteliste
- Wenn Mutex belegt: Task an Warteliste anfügt und Scheduler-Aufruf $\rightarrow$ CPU nicht blockiert
- können nicht in Interruptkontext verwendet werden
- Zugriff auf Warteliste mit spinlock serialisiert

Zusammenfassung

- Ablauf bestimmter Code-Sequenzen muss serialisiert werden
  - geteilte Datenstrukturen
  - Kommunikations mit Hardware/Geräten
- Interruptsperren, spinlocks, mutexe
- Echtzeit $\neq$ schnell
- Echtzeit-System muss auf Ereignis (Timer, externe Eingaben, etc.) innerhalb eines vorgegebenen Zeitrahmens reagieren

Scheduling-Latenz: Ursachen

- Treiber mit aufwendigen/langen ISR
- Kernel-Code, welcher längere Zeitdauer in spinlock-Region verbringt
- $\rightarrow$ Scheduling kann währenddessen nicht durchgeführt werden
- Für schnelle Reaktionen/Antwortzeiten auf Ereignisse/externe Signale ist Rescheduling nötig (z.B. jetzt wieder lauffähiges Programm ausführen)

Wie Scheduling-Latenz reduzieren?

- Scheduling nach auftreten eines Events (z.B. Interrupt) so schnell wie möglich durchführen

- Linux Kernel Preemption
  - Grundidee: Zeit zwischen Eintreten eines Ereignisses und Scheduler-Aufruf reduzieren

  $\longrightarrow$ Mehr Gelegenheiten für Scheduler-Aufruf schaffen
  - Aber wann ist es sicher, den Kernel-Prozess zu unterbrechen?

kurze Antwort: Wenn der Kernel nicht einen kritischen Abschnitt abarbeitet.

Explizites Scheduling

`cond_resched*()`-Funktionen

- Falls für längere Zeiträume keine Scheduling-Gelegenheit besteht
  - z.B., wenn über größere Datenmengen iteriert werden muss (`fs/`, `mm/`...)
  - $\rightarrow$ System weniger "Flüssig"
- Linux 2.4: "Lowlatency-Patches"
- Code-Anpassungen nötig ("lock breaking")

CONFIG_PREEMPT_VOLUNTARY

- Mehr Codestellen an denen Scheduler-Aufrufe erfolgen
- Verwendet exisitierende Debugging-Funktionalität: `might_sleep()`
  - `might_sleep()` markiert Stellen, die zu scheduling-Aufrufen führen *k*önnten
  - Mit aktiviertem `CONFIG_DEBUG_SPINLOCK_SLEEP` werden Stacktraces erzeugt, falls `might_sleep()` Aufruf innerhalb eines atomaren Kontextes (d.h. "hält spinlock" oder Interrupts abgeschaltet) erfolgt ist
  - Mit `CONFIG_PREEMPT_VOLUNTARY`:
    `might_sleep()` $\rightarrow$ `cond_resched()`

include/linux/kernel.h

```
#ifdef CONFIG_PREEMPT_VOLUNTARY
extern int cond_resched(void);
# define might_resched() cond_resched()
#else
# define might_resched() do { } while (0)
#endif

#ifdef CONFIG_DEBUG_SPINLOCK_SLEEP
 void __might_sleep(char *file, int line);
# define might_sleep() \
 do{__might_sleep(__FILE__, __LINE__); might_resched();}while(0)
#else
# define might_sleep() do { might_resched(); } while (0)
#endif
```

CONFIG_PREEMPT

- aktueller Kernelthread kann verdrängt werden (nicht in spinlocks, Interrupts, etc.)
- spinlock-Aufruf inkrementiert/dekrementiert zusätzlich per-Prozess Zähler: `preempt_count`
- etwas vereinfacht:
  - nach Abarbeitung einer ISR sowie bei Aufruf von `spin_unlock(&x)`:
  - Wenn `preempt_count == 0` und Scheduler-Aufruf nötig (z.B. weil Task t nun lauffähig ist) $\rightarrow$ `preempt_schedule()`

Wie Reaktionszeit garantieren?

Was für RT kritische Bestandteile untersucht werden müsste:

1. Interrupthandler (incl. Softirqs)

2. Scheduler

3. Alle Stellen, ...

   - an denen Interrupts deaktiviert werden
   - an denen Preemption deaktiviert wird (incl. spinlocks)

4. Alle Code-Stellen an denen Mutexe/Semaphoren verwendet werden, die auch von den RT-Bestandteilen benötigt werden

Priority Inversion-Problem (1)

Gegeben: Tasks t_1, t_2, t_3.

- t_1: kritisch, RT Priorität
- t_2: normale Priorität
- t_3: niedrige Priorität
- t_1 und t_3 teilen sich Mutex/Semaphore

Priority Inversion (2)

1. t_3: holt mutex
2. t_1: wird ablauffähig, verdrängt t_3
3. t_1: benötigt Mutex $\rightarrow$ blockiert, t_3 erhält CPU
4. diese "Priority Inversion" ist (noch) kein Problem
5. Wenn aber t_2 lauffähig wird ist t_1 auf $unbestimmte\ Zeit$ blockiert (unbouneded priority inversion)

PREEMPT_RT Patch: Ziele

- nicht-Unterbrechbare Codeanteile minimieren
- Anteil der Änderungen (gegenüber "normalem" Kernel) gering halten
- Mit `PREEMPT_RT` werden (von wenigen Ausnahmen abgesehen)...
  - kritische Abschnitte
  - Interrupt-Handler
  - Abschnitte welche Interrupts sperren

  . . . unterbrechbar
- Hochauflösende Timer
- Integration in Mainline

"Normaler Kernel":

- drei Kontexte

  1. Interrupts (nicht unterbrechbar)
  2. Softinterrupts (nicht unterbrechbar)
  3. Prozess-Kontext (ausserhalb kritischer Abschnitte unterbrechbar)

Kontexte mit PREEMPT_RT

1. ,,Harte" Interrupts (nicht unterbrechbar)
   - maskiert nur den jeweiligen Interrupt
2. Interrupt-Threads (unterbrechbar)
   - Je ein Thread per IRQ
   - Ruft alle "ISR" des jew. IRQ auf
3. Softinterrupts (unterbrechbar)
4. Prozess-Kontext (unterbrechbar)
   - Spinlock $\rightarrow$ RTMutex

Priority Inheritance

Wdh: Priority Inversion

1. t_3: holt mutex
2. t_1: wird ablauffähig, verdrängt t_3
3. t_1: benötigt Mutex $\rightarrow$ blockiert, t_3 erhält CPU

$\rightarrow$ Wenn nun t_2 lauffähig wird, so ist t_1 auf unbestimmte Zeit blockiert

Priority Inheritance "vererbt" Priorität von t_1 an t_3
$\rightarrow$ stellt sicher, das Prozess nie von einem (niedriger priorisierten) Prozess blockiert wird

RT-Mutexes

- Mutexe mit PI-Protokoll
- Ürsprünglich -rt, inzwischen in Mainline
  (für `pthread_mutex_t PTHREAD_PRIO_INHERIT`)
- Eigentümer eines RT-Mutexes erhält Priorität von wartenden Tasks mit höherere Priorität
- Falls der Eigentümer selbst auf einen anderen RT-Mutex blockt, Priorität ggf. neu vererben

RT-Mutexes (forts.)

- RT-Mutex-Warteliste: nach Priorität sortiert
- `pi_list`: Per-Task Liste mit 'Top-Waiters' aller RTMutexe des Tasks, nach Priorität sortiert
- Wenn sich erster Task dieser Liste ändert: Priorität d. Eigentümers anpassen

Reader/Writer Locks (rwlock_t)

- es wird zwischen "lesenden" und "schreibenden" Nutzern unterschieden
- rwlock kann von *mehreren* lesenden $oder$ *einem* schreibenden Task verwendet werden
- Wenn schreibender Zugriff benötigt: Es muss auf *alle* Leser gewartet werden
- Problem: Blockiert auf Unbestimmte Zeit

1. Only one task at a time may read-acquire a given reader-writer lock.
2. If $\#1$ results in performance or scalability problems, the problematic lock will be replaced with RCU (read-copy update).

RCU (read-copy update)

- Schreiber blockieren keine Leser
- Leser halten Schreiber nicht davon ab, Daten zu verändern

$\longrightarrow$ keine Priority Inversion möglich

RCU (read-copy update)

- löschoperationen werden zweigeteilt

  1. verhindern, dass zu löschende Daten noch sichtbar sind
  2. Löschoperation durchführen

- RCU ermöglicht lockfreie Lesezugriffe auf Daten, z.B. Linked List

  1. Element aus der Liste herauslösen
  2. Element löschen, nachdem kein Leser mehr eine Referenz auf dieses Element hält

RCU (forts.)

- normaler Kernel: Preemption wird während read-Zugriff abgeschaltet (`rcu_read_lock()`)
  1. Leser dürfen nicht schlafen; (RCU kritischer Abschnitt); nicht bei `PREEMPT_RT`
  2. Schreiber haben mehr arbeit: alte Daten, auf die noch zugegriffen werden kann müssen vorgehalten werden

Quiz: Wie erkennt der RCU-Mechanismus, wann alte Daten freigegeben werden können?

RCU im -rt Patchset

- RCU-Leseseite wird preemptiv: `current->rcu_read_lock_nesting`
- Neues Problem:
  - Wenn (viele) Leseseiteten zu lange blockieren: OOM
  - Gesucht: "was ähnliches wie Priority Inheritance"

RCU Priority Boosting

- RCU-Booster Task: überwacht (per-CPU) Liste mit Tasks welche RCU-Leseseitig blockiert sind
- Overhead nur dann, wenn Task blockiert ist; keine Änderung an `rcu_read_lock` etc.
- Scheduler prüft `current->rcu_read_lock_nesting`, wenn > 0: Preemption innerhalb RCU-Readseite
  - Task in Priority-Boost-Liste eintragen
- Task trägt sich selbst aus Liste aus wenn äußerste (blockierte) Leseseite beendet ist
- Booster Task kontrolliert Liste periodisch

Zustände

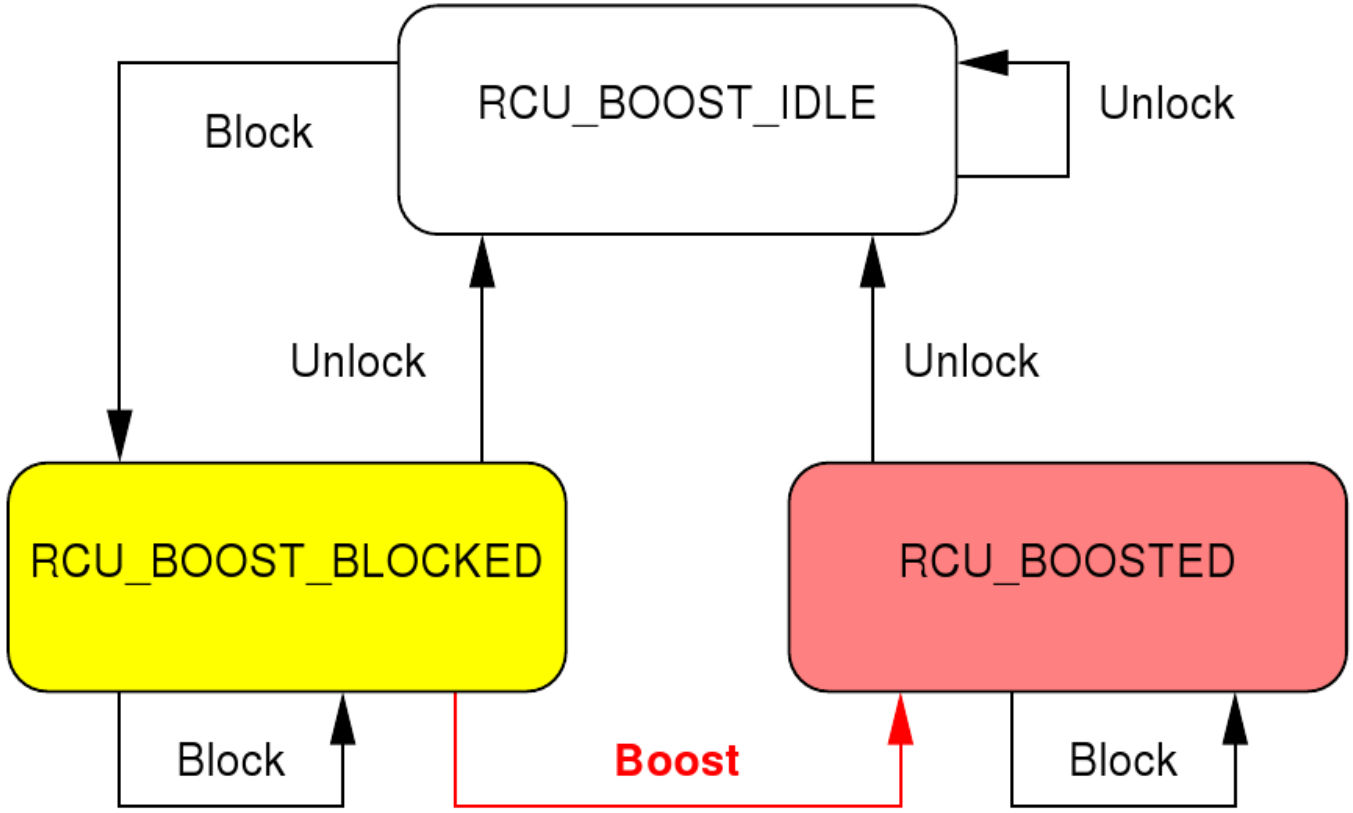

(Quelle: [2])

Linux Scheduling Klassen

- `SCHED_OTHER`: Prioritäten (`-20` (hoch) bis `19` (niedrig))
  - Die Standard-Klasse. Alle Prozesse erhalten faire CPU-Anteile. Höher Priorisierte Prozesse erhalten längere/häufigere Zeitscheiben, blockieren nierdrigere Prozesse jedoch nicht.

- `SCHED_FIFO`: Echtzeitpriorität. Es wird jeweils der höchstpriorisierte Prozess bearbeitet. Solange der Prozess nicht blockiert, wird die CPU nicht abgegeben ("`for (;;) ;`" mit `SCHED_FIFO` $\rightarrow$ alle anderen Prozesse laufen nicht mehr)

- `SCHED_RR`: '`SCHED_FIFO` mit Zeitscheiben'; bei mehreren `SCHED_RR` Prozessen gleicher Priorität laufen diese abwechselnd

Einstellen mit: `chrt(1)`, `sched_setscheduler(2)`

RTOS allein reicht nicht aus

- Hardware-Latenzen: SMI/SMM, DMA, . . .
  - SM-Interrupts liegen außerhalb der Kontrolle des Betriebssystems
  - nicht vorhersagbare/kontrollierbare Unterbrechungen
- Pagefault-Latenzen:
  - Verwendung von Dateien
  - Swap
  - `mmap`, `fopen`, . . .

RTOS allein reicht nicht aus

Anwendung muss auch geeignet entworfen werden, z.B.

- Teilen von Anwendung in RT-kritische und weniger wichtigen Teil
- Auslagern von (bestimmten) Speicherseiten mit `mlock(2)`/bzw. `mlockall(2)` deaktivieren
- allen Speicher vor betreten des RT-Bereichs anfordern und initialisieren

FIN

- mit RT-Patch wird Kernel fast vollständig preemptible
- Dazu werden z.B. ISR etc. in Kernel-Threads "ausgelagert"
  $\longrightarrow$ deterministischeres Zeitverhalten auf Kosten der Leistung
- Highres-Timer, Userspace Priority Inheritance in Mainline

Literatur

1 Darren Hart, Steve Rostedt, "Internals of the RT Patch"; Linux Symposium 2007.

2 Paul McKenney "Priority-Boosting RCU Read-Side Critical Sections"
`http://www.rdrop.com/users/paulmck/ \`
`RCU/RCUbooststate.2007.04.16a.pdf`
(RCU-Seite: `http://www.rdrop.com/users/paulmck/RCU/`)

3 RT-Wiki: `http://rt.wiki.kernel.org/`

4 RT-Patches: `http://www.kernel.org/pub/linux/kernel/projects/rt/`

5 `Documentation/rt-mutex-design.txt`